

Iranian Journal of Insurance Research

(IJIR)

Homepage: https://ijir.irc.ac.ir/?lang=en



ORIGINAL RESEARCH PAPER

Presenting an ensemble model for identifying claims of suspicious damages in agricultural insurance

Y. Ahmadlou¹, A. Pourebrahimi^{2,*}, J. Tanha³, A. Rajabzade⁴

- ¹ Department of Information Technology Management, Science and Research Branch, Islamic Azad University, Tehran, Iran
- ² Department of Industrial Management, Karaj Branch, Islamic Azad University, Karaj, Iran
- ³ Department of Information Technology Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran
- ⁴ Department of Industrial Management, Faculty of Management and Economics, Tarbiat Modares University, Tehran, Iran

ARTICLE INFO

Article History:

Received 30 May 2022 Revised 13 July 2022 Accepted 24 August 2022

Keywords:

Agricultural insurance Anomaly detection Data mining Ensemble learning Unsupervised machine learning

*Corresponding Author:

Email: a.pourebrahimi@kiau.ac.ir Phone: +9821 44210808 ORCID: 0000-0001-5741-0260 **ABSTRACT**

BACKGROUND AND OBJECTIVES: It is very difficult and maybe impossible to identify suspicious damage claims in agricultural insurance using traditional methods and using the opinions of experts among a multitude of claims. In the current research, a model for discovering suspicious damage claims in agricultural insurance using data mining techniques has been presented to help the agricultural insurance fund in identifying such claims.

METHODS: The research method in the present research is applied in terms of intention and descriptive-post-event in terms of quiddity. One of the applications of data mining is anomaly detection. In the present study, a technique for detecting anomalies in the data using ensemble machine learning models is carride out. To enforcement this method, real data on compensation paid for wheat insurance (irrigated and rainfed) for one year in Khuzestan province was used. Because of differences in the process of determining damages of irrigated and rainfed wheat insurance policies, their anomalies were analyzed separately and a number of suspicious claims were acquired for each.

FINDINGS: The analysis of the results showed 5 types of suspicious behavior in claiming damages. The ratio of suspicious claims to the total (percentage of anomalies) was estimated using the histogram of anomalous scores and the opinion of insurance fund experts about 1.5%. Suspicious and unusual cases were examined by experts and the final accuracy of the model in correctly identifying suspicious cases was 72% for irrigated wheat insurance and 68% for dryland wheat insurance.

CONCLUSION: Based on the obtianed results, the presented model can be used to detecte suspicious claims in wet and dry wheat insurance policies. Since most of the unusual cases are caused by not providing sufficient documentation, it can be due to the presentation of forging insurance policies or the existence of collusion between the insured, the agent or the assessor. Therefore, more care should be taken in the payment process. The present study was conducted on the product and can be used for other crops as well.

DOI: 10.22056/ijir.2023.01.06

This is an open access article under the CC BY license (http://creativecommons.org/licenses/by/4.0/).





نشريه علمي يژوهشنامه بيمه

سابت نشر به: https://ijir.irc.ac.ir/?lang=fa



مقاله علمي

ارائهٔ یک مدل ترکیبی برای تشخیص ادعاهای مشکوک خسارت در بیمهٔ کشاورزی

يعقوب احمدلو\، عليرضا يورابراهيمي ٢٠٠٠، جعفر تنها٦، على رجب زاده ٢

ٔ گروه مدیریت فناوری اطلاعات، دانشکدهٔ مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

ٔ گروه مدیریت صنعتی، دانشکدهٔ مدیریت و حسابداری، دانشگاه آزاد اسلامی، کرج، ایران

^۳ گروه مهندسی فناوری اطلاعات، دانشکدهٔ مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

ٔ گروه مدیریت صنعتی، دانشکدهٔ مدیریت و اقتصاد، دانشگاه تربیت مدرس، تهران، ایران

اطلاعات مقاله

تاریخ های مقاله:

تاریخ دریافت: ۰۹ خرداد ۱۴۰۱ تاریخ داوری: ۲۲ تیر ۱۴۰۱ تاریخ پذیرش: ۰۲ شهریور ۱۴۰۱

كلمات كليدى:

بيمهٔ کشاورزی تشخيص موارد غيرنرمال داده کاوی یادگیری ترکیبی یادگیری ماشینی بدون نظارت

°نویسنده مسئول:

ایمیل: A.pourebrahimi@kiau.ac.ir تلفن: ۴۴۲۱۰۸۰۸

ORCID: 0000-0001-5741-0260

پیشینه و اهداف: شناسایی ادعاهای مشکوک خسارت در بیمهٔ کشاورزی با استفاده از روشهای سنتی، با بهرهگیری از کارشناسان در میان انبوه ادعاها بسیار دشوار و شاید غیرممکن باشد. در پژوهش حاضر، مدلی برای کشف ادعاهای مشکوک خسارت در بیمهٔ کشاورزی با استفاده از تکنیکهای داده کاوی ارائه شده است تا به صندوق بیمهٔ کشاورزی در شناسایی این گونه ادعاها کمک نماید.

روش شناسی: روش تحقیق در این پژوهش از نظر هدف، کاربردی و از نظر ماهیت، توصیفی ـ پسرویدادی است. یکی از کاربردهای داده کاوی، تشخیص ناهنجاری است. در مطالعهٔ حاضر، روشی برای تشخیص ناهنجاریها در دادهها با استفاده از مدلهای ترکیبی یادگیری ماشین ارائه شده است. برای اجرای این روش، از دادههای واقعی خسارت پرداختی به بیمهٔ گندم (آبی و دیم) به مدت یک سال در استان خوزستان استفاده شده است. با توجه به تفاوت در روند تعیین خسارت بیمهنامههای گندم آبی و دیم، تحلیل ناهنجاری آنها به تفکیک انجام شده و برای هر کدام تعداد ادعاهای مشکوک به صورت جداگانه به دست آمد.

یافتهها: تجزیهوتحلیل نتایج، ۵ نوع رفتار مشکوک را در ادعای خسارت نشان داد. نسبت ادعاهای مشکوک به کل (درصد ناهنجاریها) با استفاده از هیستوگرام نمرات ناهنجاری و نظر کارشناسان صندوق بیمه حدود ۱٫۵ درصد برآورد شد. موارد مشکوک و غیرعادی توسط کارشناسان مورد بررسی قرار گرفت و دقت نهایی مدل در تشخیص صحیح موارد مشکوک برای بیمه نامهٔ گندم آبی و دیم به ترتیب ۷۲ و ۶۸ درصد به دست آمد.

نتیجه گیری: بر اساس نتایج به دست آمده، می توان از مدل ارائه شده برای شناسایی ادعاهای مشکوک خسارت در بیمهنامه های گندم آبی و دیم استفاده نمود. از آنجا که بیشتر موارد غیرعادی ناشی از عدم ارائهٔ مستندات کافی میباشد، علت این موضوع می تواند به دلیل ارائهٔ بیمه نامه های صوری یا وجود تبانی بین بیمه گذار، نمایندهٔ بیمه گر یا ارزیاب باشد. بنابراین، بایستی در روند پرداخت خسارت دقت و بررسی بیشتری صورت گیرد. مطالعهٔ حاضر بر DOI: 10.22056/ijir.2023.01.06 روى محصول گندم انجام شده و قابل استفاده براى ساير محصولات زراعي مي باشد.

مقدمه

در بیشتر مناطق با درآمد پایین، مهمترین دغدغهٔ دولتها توسعهٔ بخش کشاورزی و روستایی است. بر اساس گزارش بانک جهانی، ۴۳/۸ درصد از جمعیت جهان و ۷۵ درصد از فقیران جهان در مناطق روستایی زندگی می کنند که کشاورزی بهعنوان منبع اصلی درآمد و اشتغال آنها است (The World Bank, 2022). تأکید بر توسعهٔ بخش کشاورزی نه فقط بهدلیل ارزش ابزاری آن برای رشد سریع بخش های دیگر اقتصاد و تأمین مواد غذایی مورد نیاز کشورها، بلکه در جهت افزایش درآمد واقعی کشاورزان و ساکنین روستا است و به همین دلیل برای دولتها از اولویت برخوردار است. خطرات متعددی در فرایند تولید و بازاریابی محصولات کشاورزی وجود دارد. بیمهٔ

محصولات کشاورزی، بهعنوان یکی از ابزارهای مدیریت ریسک، با

ارائهٔ بیمه نامه هایی که چنین نوساناتی را تحت پوشش قرار می دهد،

می تواند تا حدی ثبات و امنیت مالی را برای کسانی که در این حوزه

فعالیت می کنند در پی داشته باشد (Cole and Xiong, 2017).

نیاز به یک منبع جبران خسارت به نام «بیمه»، بهدلیل پیچیدگی فعالیت های اقتصادی در جهان کنونی برای جبران ضرر و زیان ناشی از این فعالیت ها امری اجتناب ناپذیر است (Rostami and Monazamitabar, 2021). کشاورزی به عنوان تنها نهاد بیمه گر محصولات کشاورزی در ایران بوده و منابع آن از طریق بانک کشاورزی تأمین شده و درنهایت دولت هزینه های پرداختشده را پرداخت می کند. ایران که با تغییرات اقلیمی بالا در چند سال اخیر مواجه بوده، دارای ایران که با تغییرات اقلیمی بالا در چند سال اخیر مواجه بوده، دارای ریسک بسیار بالایی می باشد (پیشینهٔ بیمهٔ کشاورزی ایران). در کنار این موضوع، یکی از چالشهایی که صندوق بیمهٔ کشاورزی با آن مواجه است، ادعاهای غیرواقعی برای دریافت خسارت می باشد؛ به عبارت دیگر، پرداخت خسارت به حوادثی که اتفاق نیفتاده اند و به عنوان کلاهبرداری مطرح می باشد.

از آنجا که کلاهبرداران تمام تلاش خود را برای قانونی جلوه دادن رفتار خود به کار می برند و نیز تعداد پرونده های قانونی بسیار بیشتر از تعداد پرونده های کلاهبرداری است، بنابراین کشف آنها، به عنوان یک مسئلهٔ دشوار در بیمه مطرح می باشد. مکانیزم های دستی و سنتی و حتی سامانه های بیمه که هوشمند نیستند، قادر به تشخیص ادعاهای مشکوک نیستند و باعث می شود پرداخت های قابل توجهی به حوادث ساختگی و خسارت های غیرواقعی انجام شود. بنابراین، کشف تقلب به یکی از بهترین کاربردهای داده کاوی و یادگیری ماشین در صنعت و دولت تبديل شده است (Bouazza and Ameur, 2018). کلاهبرداران به مرور از روش های جدیدی برای تقلب استفاده می کنند و همیشه از لحاظ اطلاعات غنی تر از بیمه گر هستند. بنابراین، هدف در این پژوهش، که برای اولین بار در حوزهٔ بیمهٔ کشاورزی ایران انجام می شود، این است که با استفاده از تکنیکهای یادگیری ماشین بدون نظارت مدلی ارائه شود تا بتوان با استفاده از داده های موجود، ادعاهای مشکوک و روش های کلاهبرداری را شناسائی و از پرداخت غرامت جلوگیری به عمل آورد.

مبانی نظری پژوهش

یکی از مهم ترین مشکلات صنعت بیمه، کلاهبرداری است که به موازات رشد و گسترش این صنعت راه های کلاهبرداری و کسب درآمد نامشروع در این حوزه نیز رو به افزایش است (Rostami and Monazamitabar, 2021). افزایش است (Hosseini and Rezaei, 2019). طبق از کل حجم هزار میلیارد دلاری صنعت بیمهٔ دنیا، ۲۵ درصد آن را آمار منتشره از سوی ائتلاف ضد کلاهبرداری بیمه، سالانه حدود ۸۰ میلیارد دلار در آمریکا از طریق کلاهبرداری بیمه از مصرف کنندگان سرقت می شود. (Gill et al. (2005) کلاهبرداری بیمه ای را به این صورت تعریف کرده اند: «ادعای ساختگی خسارت به صورت آگاهانه، مالام خسارت بیش از میزان واقعی آن، یا به هر نحوی که بیمه گذار مبلغی بیش از آنچه مستحق آن است به دست آورد.» بانک ها و مؤسسات بیمه به دلیل هزینه های بسیار زیاد کلاهبرداری به دنبال مؤسسات بیمه به دلیل هزینه های بسیار زیاد کلاهبرداری به دنبال تحلیل روش های کلاهبرداران در جهت شناخت و مقابله با آن (Roholamini et al., 2020).

تقلب در انواع بیمه ها از جمله بیمهٔ کشاورزی دیده می شود. طبق تخمین، کلاهبرداری بیمهٔ محصولات زراعی تقریباً پنج درصد از کل آن را تشکیل می دهد که عدد قابلملاحظه ای است (Marzen, 2013).

تقلب در بیمهٔ کشاورزی می تواند از طریق اظهارات نادرست، خسارت ساختگی، تبانی بین عوامل شرکت بیمه گر و بیمه گذار و جابجایی در اعلام میزان بازده/عملکرد محصول رخ دهد (Crop insurance, 2006; Marzen, 2013). به عنوان مثال، در پرونده ای مربوط به کلاهبرداری بیمهٔ کشاورزی در انبار دخانیات مونت استرلینگ، کنتاکی که در سال ۲۰۱۴ رخ داده، ۴۰ نفر متهم دارد. در این پرونده، رایجترین وضعیت مربوط به کشاورزانی بود که محصول تنباکوی خوبی تولید کرده بودند اما با نمایندگان بیمه و تنظیم کنندگان خسارت تبانی کردند تا ادعا کنند محصول در اثر طوفان یا آفات نباتی آسیب دیده است. بدین صورت که کشاورز ادعای بیمه می کرد و غرامت به او پرداخت می شد. برای انجام این کار، نمایندگان بیمه و تنظیم کنندگان خسارت رشوه دریافت می کردند (Clayton, 2022).

با توجه به کاربرد گستردهٔ داده کاوی در بازارهای مالی و بیمه، می تواند به عنوان ابزاری برای تشخیص رفتارهای غیرنرمال در بیمهٔ کشاورزی پتانسیل داشته و برای کشف تقلب در بیمهٔ محصولات کشاورزی کمک کند (Rejesus et al., 2004). همچنین تکنیک های داده کاوی به منظور تعمیم مدلهای کشف ادعاهای تقلبی و ارائهٔ پیشبینی مورد استفاده قرار می گیرند (Goodarzi) در حال تعلیی و ارائهٔ پیشبینی مورد استفاده قرار می گیرند (and Janatbabaei, 2017 تبدیل شدن به یک حوزهٔ پر کاربرد راهبردی است که برای یافتن الگوهای پنهان و کشف روابط ناشناخته در مجموعه داده ها تکمک می کند (Roholamini et al., 2020). یکی از رایج ترین تشخیص ناهنجاری بوده (Kirlidog and Asuk, 2012) و به دنبال تشخیص ناهنجاری بوده (Kirlidog and Asuk, 2012) و به دنبال یافتن الگوهای متفاوت در داده هاست که با رفتار مورد انتظار و عادی

مطابقت نداشته (Chandola et al., 2009) و اغلب به منظور کشف ناهنجاریهای بیمه، کارت بانکی و تشخیص نفوذ شبکه مورد استفاده قرار می گیرد (Zhao et al., 2019).

برخلاف اکثر نرم افزارهای رایانه ای، سیستم های داده کاوی وقوع یک رویداد را با دقت ریاضی نشان نمی دهند، بلکه موارد مشکوک به کلاهبرداری را به کمک سوابق گذشته تجزیهوتحلیل کرده، امتیازی بهعنوان امتیاز ناهنجاری به هر نمونه اختصاص می دهد؛ سپس کارشناسان می توانند تحقیقات دقیق تری روی مواردی که دارای امتيازهای بالایی هستند، انجام دهند (Kirlidog and Asuk, 2012). تکنیک های یادگیری ماشینی به طور فزاینده ای به عنوان یکی از رویکردهای تشخیص ناهنجاری استفاده می شود. یادگیری ماشین تلاشی است برای «خودکار کردن فرایند کسب دانش از نمونه ها» (Bose and Mahapatra, 2001). بنابراین، تشخیص ناهنجاری را می توان بر اساس نوع دادهٔ آموزشی مورد استفاده برای ساخت مدل، به سه دستهٔ کلی تقسیم کرد: تشخیص ناهنجاری نظارت شده که در آن نمونه های عادی و غیرعادی دارای برچسب هستند، تشخیص ناهنجاری بدون نظارت که در آن نمونه ها بدون برچسب هستند و تشخیص ناهنجاری نیمه نظارتشده که آموزش در اینجا فقط شامل نمونه های عادی است؛ بنابراین، هر چیزی که نمی تواند به عنوان عادی طبقه بندی شود، به عنوان غیرعادی مشخص می شود .(Nassif *et al.*, 2021)

به گفتهٔ (2021) Gomes et al. (2021) از آنجا که الگوهای رفتاری کلاهبرداری مدام در حال تغییر هستند، تکنیک های یادگیری ماشین بدون نظارت نقش مهمی نسبت به تکنیک های نظارت شده در کشف کلاهبرداری ایفا می کند.

روش های تشخیص ناهنجاری بدون نظارت مستعد ایجاد نرخ های مثبت و منفی کاذب بالایی هستند (2016, Das et al., 2016). طبق گفتهٔ (2019, Zhao et al. (2019) طبق گفتهٔ در سناریوهای تشخیص ناهنجاری، محققان رویکردهای ترکیبی (Ensemble) را برای تشخیص ناهنجاری در پیش می گیرند. در این نوع یادگیری، چندین تخمین گر پایه (Base estimator) را برای دستیابی به عملکرد و قابلیت اطمینان بالاتر در مقایسه با یک تخمین گر ترکیب می کنند.

مروری بر پیشینهٔ پژوهش

در پژوهشی که توسط (2014) به منظور شناسایی تقلب انجام شده، از سیستم ایمنی مصنوعی به منظور شناسایی تقلب کارت های اعتباری استفاده کردهاند. آنها مدل جدیدی به نام مدل تشخیص تقلب مبتنی بر سیستم ایمنی مصنوعی که از سیستم ایمنی الهام گرفته شده، برای کشف تقلب ارائه نموده اند. مدل آنها از نوع نظارتشده بود و برای جبران زمان آموزش زیاد از رایانش ابری استفاده کردند.

در مطالعه ای که توسط (2017) Goodarzi and Janatbabaei رمطالعه ای که توسط برای بررسی عوامل مؤثر بر تقلبات بیمهٔ اتومبیل با کاربرد مدل های داده کاوی تدوین شده است، تکنیک های رایج در کشف تقلب

بیمه های اتومبیل شامل: رگرسیون لجستیک، درخت تصمیم و دستهبندی بیزین را مورد استفاده قرار داده اند. داده های مورد نیاز را از یک شرکت بزرگ بیمهای اخذ کرده بودند. آنها دادهها را به دو بخش تقسیم کردند؛ از بخش نخست برای ساخت مدل و از بخش دوم برای دسته بندی استفاده کردند. یافتههای این مطالعه نشان داده که مدل رگرسیون لجستیک دقت بیشتری برای پیشبینی کل ادعاها، اعم از تقلبی و غیرتقلبی، نسبت به دو مدل دیگر یعنی درخت تصمیم و روش بیزین ساده داشته است.

خود شف استفاده از استفاده از استفاده از پژوهشی با عنوان «کشف تقلب و راهکارهای مقابله با آن در سازمانهای بیمه ای با استفاده از داده کاوی» که بهصورت مطالعهٔ موردی در سازمان تأمین اجتماعی ایران انجام دادند، سه روش داده کاوی درخت تصمیم، کا نزدیکترین همسایه و شبکهٔ عصبی مصنوعی را مورد استفاده قرار دادند که به ترتیب درخت تصمیم با دقت ۹۹/۶۴ درصد، شبکهٔ عصبی با دقت ۹۹/۰۷ درصد و کا نزدیکترین همسایه با دقت ۹۶/۸۴ درصد دقت در تشخیص صحیح مواد کلاهبرداری موفق بودند.

Rejesus et al. (2004) از تکنیک های داده کاوی برای تشخیص شهرهایی با جریب های برداشت شدهٔ غیرنرمال استفاده کردند. آنها شهرهایی که درصد برداشت پایینی (در حد ۵ درصد و پایین تر) داشتند را پرچم گذاری کردند. آنها در کار خود از روش تشخیص موارد پرت با استفاده از امتیاز استاندارد ۲ بهره بردند.

البرد ادر کشف کلاهبرداری در حوزه های مختلف کاربرد تکنیک های داده کاوی در کشف کلاهبرداری در حوزه های مختلف مالی از جمله بیمه نشان دادند ۲۶ تکنیک برای این منظور مورد استفاده قرار می گیرد. همچنین از روش های داده کاوی که بیشترین کاربرد را در کشف تقلب داشتند، طبقه بندی ارائه نمود که عبارتند از: رگرسیون، طبقه بندی، خوشه بندی، پیشبینی، کشف موارد پرت و بصریسازی. یافته های این پژوهش نشان می دهد که تکنیک های داده کاوی بهطور گسترده برای کشف تقلب استفاده شده است.

در کار خود برای تشخیص تقلب در Verma et al. (2017) بیمهٔ سلامت از قوانین انجمنی (Associasion rules) و خوشه بندی کا-میانگین (k-means) برای شناسایی الگوهای پرتکرار تقلب که در داده های بیمه سلامت نهفته بودند، استفاده نموده و موارد غیرنرمال را با بهره گیری از تابع توزیع گاوسی مشخص کردند.

تصادفی بدون نظارت برای شناسایی کلاهبرداری بیمهٔ سلامت تصادفی بدون نظارت برای شناسایی کلاهبرداری بیمهٔ سلامت استفاده کردند، آنها این دو روش را همراه با روشهای متداول تر شامل عامل دورافتادهٔ محلی (Local outlier factor)، خودرمزگذار (Autoencoder) و کال نزدیک ترین همسایهها (neighbors مورد بررسی قرار دادند. به منظور اعتبار سنجی عملکرد تشخیص تقلب در هر روش، از پایگاه دادهٔ فهرست افراد اشرکت های مستثنی شده استفاده کردند که حاوی اطلاعات ارائه دهندگان خدمات سلامت مستثنی شده بود. نتایج بررسی نشان داد که عامل دورافتادهٔ محلی، بهترین روش تشخیص پرت/ناهنجاری است و کا دندیکترین همسایه با ۵ همسایه و رمزگذارهای خودکار بدترین

روشها در تشخیص تقلب بیمهٔ سلامت برای مجموعه دادهٔ مورد بررسی هستند.

وراد غیرعادی تراکنش های کارت اعتباری، از روش آدابوست (Adaboost) و رأی حداکثری (Majority vote) استفاده کردند. (انها در کار خود مدل های طبقه بندی از قبیل ناوی بیزین، درخت آنها در کار خود مدل های طبقه بندی از قبیل ناوی بیزین، درخت تصمیم، جنگل تصادفی، شبکه عصبی و رگرسیون لجستیک را بهصورت ترکیبی مورد استفاده قرار داده و با بهره گیری از روش های ترکیبی آدابوست و رأی حدکثری، به نتایج بهتری دست پیدا کردند. (وش علی Hassan and Abraham (2019)

تشخیص ناهنجاری ترکیبی به منظور تشخیص تقلب در بیمهٔ خود از روس در بیمهٔ خودرو استفاده کردند. آنها از سه روش درخت تصمیم، ماشین بردار پشتیبان و شبکهٔ عصبی مصنوعی به عنوان تخمین گرهای پایه استفاده کردند. برای آزمایش، روش اعتبارسنجی متقاطع ده ـ برابری مورد بهره برداری قرار گرفت. نتایج بررسی نشان از بهبود دقت مدل ترکیبی نسبت به هرکدام از مدل ها را داشت.

در تحقیق خود برای تشخیص نارسایی در Kim at el. (2020) موتور کشتی از روش یادگیری ماشین ترکیبی استفاده کردند. آنها با استفاده از 8 مقدار مختلف برای پارامتر تعداد همسایگان (8) برای الگوریتم عامل دورافتادهٔ محلی که بهعنوان تخمین گر پایه به کار گرفته شده بود، توانستند نتایج قوی تری به دست آورند.

عمیق و بینایی ماشین روشی برای شناسایی تقلب در بیمهٔ کشاورزی عمیق و بینایی ماشین روشی برای شناسایی تقلب در بیمهٔ کشاورزی ارائه دادند که قادر بود ادعاهای مشکوک خسارت ناشی از آتش سوزی را تشخیص دهد. مدل پیشنهادی آنها ورودی را از حسگرهای مادون قرمز و دمای دستگاه اینترنت اشیاء میخواند، و بهمحض عبور مقادیر سنسور از آستانههای خاص، تصاویر زمین زراعی را جمعآوری می کرد. سپس تصاویر جمعآوریشده به یک مدل تشخیص آتش که با استفاده از طبقه بندی کنندههای مختلف برای مقایسهٔ عملکرد آموزش داده شده بودند، وارد می شدند. نتایج نشان می دهد که آموزش داده شده بودند، وارد می شدند. نتایج نشان می دهد که راهحل پیشنهادی آنها دارای ۹۷ درصد دقت است.

Mouret et al. (2021) با استفاده از الگوریتم های تشخیص ناهنجاری جنگل ایزوله توانستند زمین های زراعی که رشد غیرنرمال داشتند را شناسایی کنند. آنها با استفاده از این روش موارد مشکوک را شناسایی و سپس با کمک کارشناسان زراعی نسبت به اعتبارسنجی نتایج اقدام کردند. داده های مورد استفاده، تصاویر ماهواره ای

اخذشده از آژانس فضایی اروپا برای مزارع یکی از شهرهای فرانسه بود. در ۹۵/۵ درصد موارد زمین های زراعی مشکوک به درستی تشخیص داده شدند. آنها در کار خود روشهای دیگر تشخیص ناهنجاری ماشین بردار پشتیبان تک کلاسه، خودرمزگذار و حلقهٔ احتمالات پرت محلی را نیز بررسی کردند، ولی بهدلیل پیچیدگی اَبرپارامترهای تنظیمی برای سایر تکنیک های مورد بررسی از به کارگیری آنها صرف نظر کردند.

وجه تمایز این تحقیق با تحقیقات انجام شده در وهلهٔ اول استفاده از داده های واقعی بیمهٔ کشاورزی می باشد که بعد از پیش پردازش مورد استفاده قرار گرفته و در ادامه استفاده از روش تشخیص ناهنجاری ترکیبی برای کشف ادعاهای مشکوک درخواست خسارت در بیمهٔ کشاورزی ایران می باشد.

سؤال های پژوهش

با توجه به هدفی که از انجام این تحقیق دنبال می شود، می توان سؤال های زیر را مطرح نمود:

- چه میزان از ادعاهای خسارت بیمه نامه های گندم غیرواقعی هستند؟

- تکنیک مؤثر یادگیری ماشین برای تشخیص ادعاهای مشکوک خسارت بیمه گندم چگونه می باشد؟

روش شناسی پژوهش

یادگیری ماشین بررسی می کند که چگونه رایانه هامی توانند براساس داده ها یاد بگیرند یا عملکرد خود را بهبود بخشند (Han et al., 2011). در تحقیق حاضر برای ساخت مدل یادگیری ماشین بدون نظارت، از الگوریتم های تشخیص ناهنجاری پایه و ترکیبی استفاده شده است. الگوریتم های پایه مورد استفاده شامل جنگل ایزوله، ماشین بردار پشتیبان تککلاسه و تکنیک مورد استفاده برای ترکیب نتایج الگوریتم های پایه، ترکیب انتخابی محلی در مجموعههای پرت موازی



شکل ۱: چارچوب کلی فرایند تحلیل ناهنجاری

(LSCP) مي باشد.

برای توسعهٔ مدل های یادگیری ماشین، اغلب از مجموعه داده های آماده که در منابع اینترنتی موجود هستند و توسط دانشمندان داده آماده شده، استفاده می شود؛ اما در پژوهش حاضر از داده های واقعی استفاده شده و داده های مورد نیاز از صندوق بیمهٔ کشاورزی ضمن حفظ محرمانگی مشخصات بیمه گذاران اخذ شده است. داده ها مربوط به مشخصات بیمه نامه های محصول گندم آبی و دیم برای سال زراعی ۱۳۹۹–۱۳۹۸ استان خوزستان می باشد که برای آنها خسارت پرداخت شده است. داده ها به صورت گزارش در قالب فایل اکسل از سیستم استخراج و پالایش شدند. مشخصات مجموعه دادهٔ استخراجی شامل تمام ویژگی قابل استفاده به همراه ویژگی میانگین خسارت منطقه که یک فیلد مشتق شده می باشد، در جدول ۱ لیست شده است.

مجموعه دادهٔ به دست آمده شامل ۲۱٬۰۴۳ نمونه بیمه نامهٔ گندم آبی و دیم می باشد که در سال زراعی ۱۳۹۹–۱۳۹۸ خسارت دریافت کرده اند. آماده سازی و پیش پردازش داده ها ممکن است یکی از دشوارترین مراحل در هر پروژهٔ یادگیری ماشین باشد؛ دلیل

آن این است که هر مجموعه داده به صورت خاص و متفاوت برای هر پروژهٔ یادگیری ماشین تهیه شده است. بسیاری از ویژگی های مجموعه داده در شرکت های بیمه غیرمفید، نامربوط و بی تاثیر هستند (Roholamini et al., 2020). ویژگی هایی که برای آموزش مدل های یادگیری ماشینی استفاده می شوند، تأثیر زیادی بر عملکرد مدل خواهد داشت، درنتیجه ویژگی های نامربوط یا تا حدی مرتبط می تواند بر عملکرد مدل تأثیر منفی بگذارند (Brownlee, 2020)؛ همچنین اگر داده های ورودی به دقت غربال نشوند، مدل به دست آمده روی داده های جدید عملکرد خوبی نخواهد داشت به دست آمده روی داده های جدید عملکرد خوبی نخواهد داشت و پیش پردازش برای بهبود کیفیت مجموعه داده به کار گرفته شدند.

یاک سازی داده ها

در ابتدا ویژگی هایی که مقادیر ازدست رفته داشتند تکمیل شده و متناسب با نوع ویژگی مقادیر مناسب بر اساس مقادیر مشابه انتخاب و تکمیل شدند. برای مثال، برای بیمه گذاری که دارای چندین بیمه نامه بود و در برخی از نمونه ها ویژگی نام نماینده خالی بود، با

جدول ١: مشخصات مجموعهداده

توضيح	نوع مقياس	نوع داده	نام ویژگی	ردیف
شناسهٔ یکتا که برای هر قطعه زمین بیمهشده در سیستم تولید میشود.	اسمى	عدد صحيح	شناسهٔ قلم بیمهشده	١
شناسهٔ یکتا که برای هر بیمهنامه صادر شده در سیستم تولید میشود.	اسمى	عدد صحيح	شناسة بيمهنامه	۲
آبی یا دیم	اسمى	رشتهای	نوع كشت	٣
نام یکی از ۳۱ استان کشور	اسمى	رشتها <i>ی</i>	استان	۴
نام شهر	اسمى	رشتهای	شهر	۵
نام شعبهٔ بانک کشاورزی	اسمى	رشتهای	شعبه	۶
نام دهستان	اسمى	رشتهای	نام دهستان	٧
نام محل کشت	اسمى	رشتهای	محل	٨
حداكثر تعهد بيمهگر	نسبى	عدد صحيح	میزان تعهد کلی	٩
پایه، تکمیلی	اسمى	رشتهای	نوع بيمه	١.
ميزان غرامت پرداخت شده	نسبى	عدد صحيح	مبلغ غرامت پرداختي	11
تاريخ وقوع خسارت	فاصلهای	تاريخ	تاريخ وقوع	١٣
	اسمى	رشتهای	نام بيمه گذار	14
	اسمى	رشتهای	نام صادر كننده	۱۵
نام بيمهگر	اسمى	رشتهای	نماینده بیمهگر	18
ميزان هكتار بيمهشده	نسبى	عدد اعشاری	مساحت بيمهشده	۱۷
میزان هکتار خسارت دیده شده	نسبى	عدد صحيح	مساحت خسارتديده	١٨
مبلغ حق بيمة سهم كشاورز	نسبى	عدد صحيح	حق بيمهٔ كشاورز	۱۹
شامل: انفرادی، عمومی، پایه، تجمیعی،	اسمى	رشتهای	نوع طرح	۲.
شامل: طوفان، تگرگ، سیل، سرما و یخبندان، خشکسالی، باد گرم	اسمى	رشتهای	عامل خسارت	۲۱
نام ارزیاب	اسمى	رشتهای	ارزیاب میانگین مساحت	77
فیلد مشتقشده از ویژگی میزان مساحت خسارتدیده که نشاندهندهٔ میانگین خسارت منطقه میباشد.	نسبى	عدد اعشاری	ت یی خسارت دیده شده منطقه	77

استفاده از اطلاعات سایر بیمه نامه های آن بیمه گذار تکمیل گردید؛ طبق گفتهٔ کارشناسان صندوق بیمه، بیمه نامه ها برای هر بیمه گذار در یک محل توسط یک نماینده صادر می شود. همچنین نمونه هایی که امکان تکمیل مقادیر ازدسترفتهٔ آنها بههیچ وجه میسر نبود، حذف شدند.

مجموعه داده دارای نمونه های تکراری بودند، که ناشی از عدم درج حدود اربعه و مختصات جغرافیایی محل بیمه شده بود. لذا در ادامه تعداد ۳٬۰۲۳ نمونهٔ تکراری از مجموعه داده حذف شدند. وجود نمونه های تکراری تأثیر مثبتی در فرایند یادگیری نداشته و می تواند در عملکرد یادگیری مدل تأثیر منفی داشته باشد (Brownlee, 2020). بعد از حذف موارد تکراری، درنهایت تعداد ۱۸٬۰۲۰ نمونه در مجموعه دادهٔ نهایی باقی ماندند، که از این تعداد ۲۱٬۲۹۳ نمونه مربوط به ادعاهای خسارت بیمهٔ گندم آبی و ۶٬۷۲۷ نمونه مربوط به گندم دیم بود.

برای انتخاب ویژگی در یادگیری نظارت شده، اغلب از روش فیلتر برای فیلتر کردن ویژگی های مرتبط به برچسب استفاده شده و در یادگیری بدون نظارت، اغلب از روش همبستگی برای انتخاب ويژگى استفاده مى شود (Brownlee, 2020). طبق گفتهٔ Brownlee, (2020) انتخاب ویژگی در یادگیری بدون نظارت به تکنیکهای کاهش ابعاد مرتبط است، زیرا هر دو روش به دنبال متغیرهای ورودی کمتر برای یک مدل یادگیری هستند. از روش های کاهش بعد می توان به تحلیل مؤلفه های اصلی و خودرمزگذار اشاره کرد، که اگر خودرمزگذار با تابع فعال سازی خطی مورد استفاده قرار گیرد، معادل تحلیل مؤلفه های اصلی خواهد بود. در پژوهش حاضر بهدلیل عدم وجود متغیر برچسب، نمی توان از روش فیلتر برای انتخاب ویژگی استفاده کرد، در مواردی که تعداد ویژگی ها کم است به جای استفاده از روش های کاهش ابعاد می توان زیرمجموعه هایی از ویژگی ها را انتخاب و مدل را ارزیابی کرد (Brownlee, 2020). لذا پس از استخراج اولیه، با توجه به تعداد ویژگی ها که تعدادشان به ۲۳ رسید، زیرمجموعه ای از ویژگی های تأثیرگذار در تقلب با نظر كارشناسان حوزهٔ بازرسي صندوق بيمه انتخاب و بقيه از مجموعه داده حذف شدند، که درنهایت ۱۳ ویژگی انتخاب شد.

برای مثال، با انتخاب ویژگی «محل» که زمین زراعی بیمه شده در آنجا قرار گرفته بود، سایر ویژگی های نشان دهندهٔ محل از قبیل استان، شهر، دهستان و شعبه حذف شدند؛ چرا که ویژگی «محل» نمایان گر همهٔ این ویژگی ها می باشد. شناسه ها نیز از مجموعه دادهٔ نهایی حذف شدند. تأکید شده که برای عملکرد بهینهٔ مدل، بایستی ویژگی هایی که دارای مقادیر یکتا هستند حذف شوند (Brownlee, 2020).

آمادهسازي دادهها

از آنجا که اکثر مدل های یادگیری ماشین مقادیر عددی را به عنوان ورودی قبول می کنند، برای این منظور عملیات تبدیل بر روی ویژگی های اسمی (دسته ای) انجام گرفت. برای این کار، از روش کدگذاری باینری استفاده شد. در این تکنیک، ابتدا دسته ها بهصورت ترتیبی عددگذاری می شوند، سپس آن اعداد به کد باینری

تبدیل شده و ارقام آن رشتهٔ باینری به ستون های جداگانه تقسیم می شوند. در این روش داده ها در ابعاد کمتری نسبت به کدگذاری وان هات (One hot) تبدیل می شوند. برای کدگذاری ویژگی تاریخ وقوع خسارت، ابتدا از قالب شمسی به میلادی، سپس به قالب یونیکس تبدیل گردید. در این فرمت، تاریخ وقوع از مبدأ آن (۱۹۷۰/۰۱/۰۱) که معادل با صفر می باشد بر اساس ثانیه محاسبه شده و معادل عددی آن جایگزین تاریخ وقوع در جدول نهایی می شود. درنهایت، بعد از تبدیل تمام ویژگی های غیرعددی، تعداد نهایی ویژگی ها به عدد رسید.

بسیاری از الگوریتمهای یادگیری ماشین زمانی که متغیرهای ورودی آن عدد باشد، اگر در محدودهٔ استاندارد مقیاس بندی شوند، عملکرد تفریق میانگین از داده ها .(Brownlee, 2020) بهتری خواهند داشت را مرکزیت و تقسیم بر انحراف معیار را مقیاس بندی می نامند. لذا، این روش گاهی اوقات مقیاس بندی استاندارد مرکزی نیز نامیده این روش تبدیل مقیاس متغیرها، از رابطهٔ زیر استفاده می شود عمی شود. برای تبدیل مقیاس متغیرها، از رابطهٔ زیر استفاده می شود

$$y = \frac{x - mean(x)}{sqrt(var(x))} \tag{1}$$

که در آن میانگین به صورت زیر محاسبه می شود:

$$mean(x) = \frac{1}{N} \sum_{i=1}^{N} x_i$$
 (2)

مقیاس بندی، میانگین داده ها را صفر و انحراف معیار آن را یک می کند. در مقیاس بندی، شکل توزیع داده های مقیاس بندی شده فرقی با توزیع داده های اصلی نخواهد داشت و فقط مقیاس محور افقی تغییر می کند.

تجزيه وتحليل دادهها

در این بخش، به تشریح اِعمال الگوریتم تشخیص کلاهبرداری بر روی مجموعه دادهٔ پیش پردازششده پرداخته می شود. همان طور که در بخش های قبلی نیز ذکر شد، این مطالعه یک رویکرد بدون نظارت را اتخاذ می کند، زیرا هیچ متغیر هدفی در مورد نرمال یا غیرنرمال بودن درخواست خسارت در مجموعه داده وجود ندارد. یک مدل بدون نظارت، روابط و الگوهای درون مجموعه داده بدون برچسب را یاد می گیرد، بنابراین، اغلب برای کشف روندهای ذاتی و هزینهٔ بالای برچسب گذاری اغلب برای تشخیص ناهنجاری از رویکرد هزینهٔ بالای برچسب گذاری اغلب برای تشخیص ناهنجاری از رویکرد بدون نظارت فرض می کند که تمام دادههای آموزشی وضعیت نرمال دارند، بنابراین، اگر یک مشاهدهٔ جدید تفاوت زیادی را داشته باشد، یک ناهنجاری در بیمهٔ ناهنجاری محسوب می شود. هدف از تشخیص ناهنجاری در بیمهٔ ناهنجاری محسوب می شود. هدف از تشخیص ناهنجاری در بیمهٔ کشاورزی، شناسایی نمونه های غیرنرمال خسارت های پرداختشدهٔ مشکوک می باشد. به طور دقیق تر اگر بیان شود، یک ناهنجاری را

به عنوان نمونه داده ای تعریف می کنیم که توسط فرایندی تولید می شود که با فرایند تولید نمونه های دادهٔ نرمال متفاوت است. ناهنجاری ها معمولاً درصد کمی (معمولاً یک درصد یا پایین تر) از کل داده ها را تشکیل می دهند (Das et al., 2016).

برای کاهش ریسک استفاده از یک مدل تشخیص ناهنجاری، متخصصان ترجیح میدهند مجموعه ای از مدلهای تشخیص ناهنجاری پایه با اَبرپارامترهای مختلف بسازند؛ بهعنوان مثال، الگوریتمهای مختلف با پارامترهای متفاوت و ترکیبی متمایز از ویژگی های مجموعه داده (Aggarwal and Sathe, 2017). رویکرد تشخیص ناهنجاری گروهی، که چندین الگوریتم پایه را در تشخیص ناهنجاری ترکیب می کند، به عنوان یک استراتژی برای بهبود دقت و پایداری مدل در نظر گرفته می شود، زیرا می توان با اجرای چندین بار مدل، تأثیر واریانس در دقت مدل سازی را کاهش داد (2013) (Aggarwal, 2013) در ادامه، الگوریتم های پایه و الگوریتم ترکیبی مورد استفاده در تحقیق، مورد بررسی قرار می گیرند.

الگوريتم هاي يايهٔ تشخيص ناهنجاري

در این مطالعه از دو الگوریتم که در تشخیص ناهنجاری کاربرد دارند به عنوان الگوریتم های پایهٔ مدل ترکیبی استفاده شده است. الگوریتم ها طوری انتخاب شدند تا بتوان ناهنجاری های مجموعهداده را براساس روش های مختلف تحلیل کرد. این الگوریتم ها شامل جنگل ایزوله و ماشین بردار پشتیبان تککلاسه می باشند.

الگوريتم جنگل ايزوله

الگوریتم جنگل ایزوله یک روش مبتنی بر درخت تصميم (Liu et al., 2008) و فاصله (Ruff et al., 2008) است که برای اولین بار توسط (2008) Liu et al. ارائه گردید. ایدهٔ اصلی آنها برای طراحی این الگوریتم، وجود دو ویژگی متداول در دادههای ناهنجار بود: ۱) آنها در اقلیت هستند و از تعداد نمونههای کمتری تشکیل شدهاند و ۲) مقادیر نمونه های ناهنجار بسیار متفاوت از نمونههای عادی هستند. این الگوریتم مجموعهای از درختان ایزوله را برای یک مجموعهداده می سازد، سپس نمونه هایی را که طول مسیر متوسط کوتاهی در درختان ایزوله دارند به عنوان نمونه های ناهنجار شناسایی می کند. در این روش تنها دو متغیر وجود دارد: تعداد درخت برای ساخت و اندازهٔ زیرنمونه. این الگوریتم رویکرد متفاوتی نسبت به سایر الگوریتم ها ارائه می دهد و آن شناسایی ناهنجاری ها با جداسازی نمونه ها بدون تكيه بر فاصله و چگالى مى باشد (Liu et al., 2008). در الگوریتم جنگل ایزوله، درخت ایزوله بهصورت زیر ساخته مي شود (Liu *et al.*, 2012):

فرض کنید مجموعه دادهٔ $X = \{x_1, ..., x_n\}$ را داشته باشیم:

ا - اگر $1 \ge |X|$ باشد یا ارتفاع درخت به یک حد از پیش تعریف شده I رسیده باشد یک گره برگ ساخته شود.

۲- در غیر این صورت:

الف: انتخاب تصادفی یک ویژگی q از میان تمامی ویژگی های

X موجود در مجموعه دادهٔ

ب: انتخاب کمترین و بیشترین مقدار در ویژگی q به نامهای max و min

ج: انتخاب تصادفی یک مقدار p بین min و max

د: انجام آزمون q<p :

ساخت یک گره داخلی $X \subseteq X$ به عنوان فرزند چپ درخت، طوری که ویژگی q تمامی عناصر مجموعهٔ X کمتر از q باشد و فراخوانی مجدد الگوریتم بر روی این مجموعه از داده ها

- ساخت یک گره داخلی $X \subseteq X$ به عنوان فرزند راست درخت، p معاوی که ویژگی q تمامی عناصر مجموعهٔ q برزگتر یا مساوی باشد و فراخوانی مجدد الگوریتم بر روی این مجموعه از داده ها ارتفاع مسیر نیز به این صورت تعریف می شود (Liu $et \ al.$):

ارتفاع مسیر نقطه x (h(x))یا طول مسیر با تعداد یال هایی که از گره ریشه x یک درخت ایزوله شروع و تا یک گره خارجی ادامه مییابد، اندازه گیری می شود. طول مسیر به عنوان معیاری برای میزان حساسیت به ایزوله بودن به کار گرفته می شود:

- طول مسیر کوتاه به معنای حساسیت زیاد به ایزوله،
- طول مسیر طولانی به معنای حساسیت کم به ایزوله است. از آنجایی که درخت ایزوله ساختاری معادل درخت جستجوی باینری دارد، لذا تخمین میانگین h(x) برای خاتمهٔ گره های خارجی مانند جستوجوهای ناموفق در درخت جستوجوی دودویی است؛ در یک نمونه داده Ψ میانگین طول مسیر جستجوهای ناموفق در درخت جستجوی باینری به صورت زیر می باشد:

$$c(\psi) = \begin{cases} 2H(\psi - 1) - \frac{2(\psi - 1)}{n} & \text{for } \psi > 2, \\ 1 & \text{for } \psi = 2, \\ 0 & \text{otherwise.} \end{cases}$$
(7)

که در آن H(i) عدد هارمونیک است و می توان آن را با H(i)+۰.۵۷۷۲۱۵۶۶۴۹ (ثابت اویلر) تخمین زد. از آن آنجا که C(i) میانگین D(i) داده شده است، می توان از آن برای نرمال سازی D(i) استفاده کرد. امتیاز ناهنجاری یک نمونه D(i) به صورت زیر تعریف می شود (Liu et al., 2012):

$$s(x, \psi) = 2^{-\frac{E(h(x))}{c(\psi)}}$$
(*)

که در آن E(h(x)) میانگین h(x) از مجموع در خت ایزوله است. با استفاده از امتیاز ناهنجاری B(x)، میتوان ارزیابی زیر را انجام داد:

- اگر مقدار S برای نمونهها بسیار نزدیک به ۱ باشند، قطعاً آنها ناهنجاری هستند؛
- اگر مقدار S بسیار کوچکتر از ۰/۵ باشند، قطعا عادی هستند؛ و
- اگر برای همه نمونه ها مقدار تقریبا ۰/۵ را برگرداند، در کل نمونه ها هیچ ناهنجاری مشخصی وجود ندارد.

ماشین بردار پشتیبان تک کلاسه

Muller et al. (2018) و Schölkopf et al. (2001) یک روش ماشین بردار پشتیبانی ارائه کرده اند که بهعنوان طبقه بندی تککلاسه شناخته می شود. طبقه بندی تککلاسه (Muller et al., 2018) یک مسئلهٔ یادگیری بدون نظارت است (Ruller et al., 2018) و که طبقهبندی کننده مبتنی بر هسته با حداکثر حاشیه از مبدأ در فضای ویژگی پیدا می کند (Schölkopf et al., 2001) و می تواند برای یک مشکل تشخیص ناهنجاری یا پرت استفاده شود (Muller et al., 2018) دادههای چندوجهی، غیرخطی و غیرمحدب(Barbado et al., 2022) مناسب است.

طبق گفتهٔ (1999) Schölkopf et al. مراحل کشف ناهنجاری در ماشین بردار پشتیبان تککلاسه بهصورت زیر می باشد:

- ۱- نگاشت نقاط به فضای با ابعاد بالاتر؛
- ۲- جداسازی تمام نقاط داده از مبدأ در فضای ویژگی با استفاده از ابرصفحه؛
- ۳– استفاده از پارامتر (۷) به عنوان کسری از نقاط ناهنجار در
 داده ها؛
 - ۱- به حداکثر رساندن فاصله بین اَبرصفحه و مبدأ؛
- ۵- شناسایی نقاط زیر ابرصفحه که نزدیک به مبدأ هستند به عنوان نقاط پرت.

ماشین بردار پشتیبان تک کلاسه همان طور که در Schölkopf et al. (2001) فرموله شده، مجموعه ای را تخمین می زند که بیشترین نمونهٔ دادهشده از m نقطه $\{x_i\}_{i=1}^m$, $x_i \in \mathbb{R}^d$ را شامل شود. هر نقطه x_i توسط یک نگاشت $\varphi \colon \mathbb{R}^d o K$ از فضای ویژگی به فضای هسته با ابعاد بالای K که توسط هسته k(x,y) تولید ${}^d\mathbb{R}$ $k(x, y) = (\varphi(x), \varphi(y))$ می شود، تبدیل می شود. هسته از طریق به یک نمونهٔ داخلی در فضای هسته مرتبط می شود. ماشین بردار پشتیبان تککلاسه یک اُبرصفحه را در فضای هسته پیدا می کند که داده ها را از مبدأ با حداکثر حاشیه جدا می کند. اگر چنین اجازه (Slack) ξ , سست کوجود نداشته باشد، متغیرهای سست (Slack) اجازه می دهند که برخی از نقاط در حاشیه (پرت) باشند و مقدار آن توسط یارامتر [۰٫۱] €۷ کنترل می شود. بهطور کلی، ۷ یک کران بالا در کسری از نقاط پرت مشخص می کند. ابرصفحه در فضای هسته یک سطح غیرخطی در فضای ویژگی ایجاد می کند. بطور دقیق تر اگر بیان شود، ماشین بردار پشتیبان تک کلاسه، معادلهٔ درجه دوم زیر را حل مي کند:

$$\min_{w, \, \xi, \, \rho} \frac{1}{2} ||w||^2 + \frac{1}{v \, m} \sum_{i=1}^m \xi_i - \rho$$

$$s. \, t. \left(w, \phi(x_i) \right) \ge \rho - \xi_i, \, \xi_i \ge 0, \, i = 1, 2, ..., m$$
(a)

که در آن w بردار نرمال به ابرصفحه بوده و ρ به عنوان حاشیه

می باشد. معادلهٔ درجه دوم را می توان با استفاده از بهینه ساز متوالی کمینه حل کرد. تابع تصمیم بهصورت زیر خواهد بود:

$$g(x) = sign((w, \rho(x)) - \rho)$$
(6)

که مشخص می کند نقطهٔ X در داخل (مثبت) یا خارج (منفی) از مجموعهٔ تخمین زدهشده قرار گرفته است.

هستهٔ گاوسی تنها هسته ای است که با موفقیت در ماشین بردار پشتیبان تک کلاسه اعمال شده (Schölkopf et al., 2001) و به صورت زیر می باشد:

$$k(x,y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right)$$
 (Y)

به این هسته، هستهٔ تابع پایهٔ شعاعی نیز گفته می شود.

الگوريتم تشخيص ناهنجاري تركيبي

همان طور که در بخش های قبلی به آن اشاره شد، برای جبران ماهیت ناپایدار الگوریتمهای بدون نظارت، متخصصان حوزههای پرمخاطره مانند مالی، سلامت و امنیت، ترجیح میدهند گروهی از مدل ها را برای ترکیب و تحلیل بسازند (Zhao et al., 2021). در اين مطالعه از الگوريتم تشخيص ناهنجاري «تركيب انتخابي محلي در مجموعههای پرت موازی» (Locally Selective Combination in Parallel Outlier Ensembles) استفاده شده است. این الگوريتم به عنوان يک چارچوب کلي، با انواع مختلف الگوريتم هاي تشخیص دهندهٔ یایه سازگار می باشد (Zhao et al., 2019). یکی از دلایل اصلی کاهش عملکرد الگوریتم های تشخیص ناهنجاری بدون نظارت، وجود ساختار دادهٔ محلى مى باشد. همچنين فقدان مقادير برچسب در رویکرد بدون نظارت، ترکیب تشخیص دهنده های پایه را با چالش جدى مواجه كرده است (Zhao et al., 2019). اين الگوريتم سعی می کند مشکل را با شناسایی مناطق محلی به دست آمده از نزدیکترین همسایهٔ خود و ایجاد تشخیص دهندهٔ رقابتی برای هر منطقهٔ محلی حل کرده و نتایج قوی تری را ارائه دهد.

همان طور که در شکل ۲ نشان داده شده است، این الگوریتم از چهار مرحلهٔ اصلی تشکیل شده است. در مرحلهٔ اول، برچسب های شبه هدف از مجموعهدادهٔ آموزشی تولید می شود. فرض کنید متعیص دهنده های آموزشی باشد و $C=\{C_{I},C_{I},...,C_{R}\}$ مجموعه ای از تشخیص دهنده های آموزشی باشد و $C(X_{train})$ متفاوت باشد. همچنین، فرض کنید $C(X_{train})$ ماتریس امتیاز ناهنجاری $C(X_{train})$,..., $C_{I}(X_{train})$ = $C_{I}(X_{train})$ میشود، با تجمیع باشد. سپس، شبه هدف که با $C(X_{train})$ نشان داده می شود، با تجمیع باشد. سپس، شبه هدف که با $C(X_{train})$ ناهنجاری تشخیص دهنده های پایه $C(X_{train})$ به یکی از روش های میانگین گرفتن یا حداکثر کردن $C(X_{train})$ به دست می آید:

$$target = \phi(O(X_{train})) \in R^{n \times l}$$
 (A)

برچسب شبه هدف در این الگوریتم با استفاده از داده های

آموزشی تولید می شود و صرفاً برای انتخاب تشخیص دهنده استفاده می شود.

در مرحلهٔ دوم، منطقهٔ محلی ساخته می شود. با توجه به یک نمونه داده برای آزمایش X_i منطقهٔ محلی Y_i به عنوان کاـ نزدیکترین همسایهٔ آن به صورت زیر تعریف می شود:

$$\Psi_{i} = \{x_{i} | x_{i} \in X_{train'} \ xi \in L_{k' \in NS}(x_{i})\}$$

$$\tag{9}$$

برای تعریف منطقهٔ محلی t $L_{KENS}(x_j)$ ، t گروه از ویژگی های $\left[\frac{d}{2},d\right]$ به صورت تصادفی برای ساخت فضای ویژگی جدید انتخاب می شود. سیس کا _ نزدیک ترین همسایهٔ داده شناسایی شده و وقتی X_i بیش از $\frac{t}{2}$ بار در همسایگی ظاهر شود به $L_{KENS}(x_j)$ اضافه شده و منطقهٔ محلی تعریف می شود. اندازهٔ منطقهٔ محلی مشخص نیست، زیرا به تعداد داده های آموزشی که معیارهای انتخاب را دارند بستگی دارد. مقدار تعداد همسایه در مسائل بدون نظارت که بر چسب ندارند و در آن نمی توان از اعتبار سنجی متقابل استفاده کرد، در بازه و در آن یشنهاد شده است.

در مرحلهٔ سوم، انتخاب مدل و ترکیب انجام می شود. برای هر نمونهٔ آزمایشی، شبه هدف محلی i را می توان با بازیابی مقادیر مرتبط با منطقه محلی i از هدف به دست آورد:

$$target^{\Psi_j} = \{target_{x_i} | x_i \in \Psi_j\} \in \mathbb{R}^{|\Psi_j| \times 1}$$
 (\cdot\cdot)

به طور مشابه، امتیاز ناهنجاری آموزش محلی $O(\Psi j)$ را می توان از ماتریس امتیاز ناهنجاری آموزشی از پیش محاسبه شده (Xtrain) به دست آورد:

$$O(\Psi j) = [C1(\Psi j),...,Cr(\Psi j)] \in R^{|\Psi_j| \times R}$$
(11)


همچنین، اگر $O(\Psi_f)$ ماتریس امتیاز آموزشی بوده و از ماتریس امتیاز ناهنجازی به دست آمده باشد، همبستگی

بین هر تشخیص دهندهٔ پایه و شبه هدف در منطقهٔ محلی قابل محاسبه می باشد. همبستگی پیرسون بین (Ψ') و $target^{\Psi_j}$


در مرحلهٔ آخر، یک هیستوگرام از امتیاز همبستگی پیرسون برای b هر یک از تشخیص دهنده ها ساخته شده و با فواصل مساوی درج میشود. سپس مجموعه ای از تشخیص دهنده های مربوط به پرتکرارترین فواصل برای ترکیب در مرحلهٔ بعدی نگهداری می شود. چارچوب کلی الگوریتم در شکل T نشان داده شده است.

نتایج و بحث


در این بخش به شرح مدل سازی کشف ناهنجاری و همچنین استخراج نتایج از آن پرداخته می شود. برای ایجاد یک مدل ترکیبی تشخیص ناهنجاری از دو الگوریتم جنگل ایزوله و ماشین بردار پشتیبان تک کلاسه به عنوان مدل های پایه استفاده شده است. برای افزایش قدرت تشخیص دهندهٔ ترکیبی نیاز است تا انواع تشخیص دهنده های پایهٔ مختلف با پارامترهای متفاوت تنظیم گردد. بنابراین، هر کدام از این الگوریتم های پایهٔ تشخیص با ۶ ابرپارامتر مختلف تنظیم شده و در مجموع ۱۲ تشخیص دهنده بهعنوان تشخیص دهنده های پایه به عنوان ورودی به الگوریتم داده می شود. برای تعیین ابرپارامتر تعداد درخت در جنگل ایزوله، ۶ عدد بهصورت تصادفی در بازهٔ ۱۰ الی ۲۰۰ لحاظ شده است. هستهٔ ماشین بردار پشتیبان از نوع تابع پایهٔ شعاعی انتخاب شد. پارامتر نو (۷) که هم یک کران پایین برای تعداد نمونه هایی است که بردارهای پشتیبان هستند و هم یک کران بالا برای تعداد نمونه هایی که در سمت اشتباه اُبرصفحه قرار دارند و معمولاً معادل با ميزان آلودگي مجموعه در نظر گرفته می شود. با مشورت کارشناسان صندوق بیمه ۶ عدد برای ابرپارامتر میزان آلودگی یا ناهنجاری احتمالی در مجموعه داده در بازهٔ ۱ الی ۲ لحاظ گردید. پارامتر گاما به عنوان ضریب هسته در اين الگوريتم، براي تنظيم ميزان تأثير نمونهٔ آموزشي مورد استفاده قرار می گیرد. هرچه این پارامتر بزرگتر باشد، نقاط نزدیک به خط جداکننده انتخاب می شوند و هرچه کوچکتر باشد، نقاط دورتر انتخاب می شوند. مقدار پیش فرض برای این پارامتر در الگوریتم



شکل ۲: چارچوب کلی الگوریتم «ترکیب انتخابی محلی در مجموعههای پرت موازی» (Zhao et al., 2019)



شکل ۳: دیاگرام کلی تشخیص ناهنجاری ترکیبی



شکل ۴: هیستوگرام امتیازات ناهنجاری گندم آبی


جدول ۲: تعداد ناهنجاری ها در آستانه های مختلف (گندم آبی)

تعداد ناهنجارى	مقدار آستانه		
۵۶۵	٠/٩۵		
444	+/9Y		
14+	٠/٩٨۵		
117	•/٩٩		
٣۴	•/99Y		
١٢	•/٩٩٩		

 $\frac{1}{\sum_{\mathrm{Taule}\,\,\mathrm{gg}(\mathcal{S}_{\mathrm{pol}})}}$ تنظیم شده است. برای این پارامتر نیز ۶ مقدار تصادفی بین ۱۰۰۰ الی ۱۰۰۰ در نظر گرفته شد.

مراحل آماده سازی داده ها در محیط های اکسل، سیستم مدیریت پایگاه داده مایکروسافت (MS-SQL) و پایتون نسخه ۲/۱۰ کلمت و کلمت و کلمت انجام گرفت. از جعبهابزار PyOD که توسط (2019) معرفی شده، برای پیاده سازی مدل استفاده گردید. این جعبهابزار شامل الگوریتم های کشف ناهنجاری است که برای محیط پایتون

تهیه شده است. از امکانات گوگل برای تحقیقات علوم داده (Colab) استفاده شد. در این محیط منابع قابلدسترس شامل ۱۳ گیگابایت حافظه و پردازندهٔ دو هسته ای ۲/۲ گیگاهرتزی بود. شکل ۳ شمای کلی مدل پیاده سازی شده برای کشف ناهنجاری را نشان می دهد. نمودار هیستوگرام امتیازهای ناهنجاری برای بیمه نامه های گندم آبی استان خوزستان حاصل از اجرای الگوریتم «ترکیب انتخابی محلی در مجموعههای پرت موازی» در شکل ۴ نشان داده شده است. خطوط نقطه چین عمودی قرمز رنگ، آستانه های ناهنجاری



شکل ۵: هیستوگرام امتیازات ناهنجاری گندم دیم

جدول ۳: تعداد ناهنجاری ها در آستانه های مختلف (گندم دیم)

تعداد موارد ناهنجار	مقدار آستانه	
٣٣٧	٠/٩۵	
7.7	•/97	
9.7	٠/٩٨۵	
۶۸	٠/٩٩	
71	•/997	
γ	•/٩٩٩	

را با مقادیر صدک متفاوت نشان می دهد. در جدول ۲ تعداد موارد ناهنجار در صدک های متفاوت آورده شده است. همان طور که مشاهده می شود، در صدک 1/4 تعداد موارد ناهنجاز برابر 1/4 مورد می باشد که 1/4 درصد از مجموع داده های بیمه نامهٔ گندم آبی است و با مقدار آلودگی که کارشناسان پیش بینی می کردند مطابق دارد. بنابراین، این آستانه برای ناهنجاری انتخاب می شود.

برای داده های گندم دیم نیز نمودار هیستوگرام امتیازهای ناهنجاری در شکل α و اطلاعات ناهنجاری و آستانه ها در جدول تنشان داده شده است:

همان طور که مشاهده می شود، در جدول ۳ برای آستانه ۱/۹۸۵ تعداد ۹۷ ناهنجاری تشخیص داده شده که حدود ۱/۵ درصد از مجموع داده های بیمهٔ گندم دیم که ۶٬۷۲۷ مورد بود، می باشد.

چالش اصلی در یادگیری بدون نظارت، ارزیابی نتایج آن است، زیرا معمولاً روی دادههایی اعمال می شوند که دارای برچسب نیستند؛ لذا برای پوشش این مسئله از کارشناسان خبرهٔ آن حوزه در ارزیابی نتایج بهره گرفته می شود. بنابراین، در قدم بعدی بیمه نامه هایی که به عنوان موارد غیرنرمال یا ناهنجار شناسایی شده بودند توسط گروهی از کارشناسان حوزهٔ بازرسی صندوق بیمهٔ کشاورزی مورد بررسی قرار گرفت تا صحت هرکدام مورد سنجش قرار گیرد. در

بررسی صورت گرفته شده، مشخص گردید که ناهنجاری های شناسایی شده توسط مدل در ۵ دسته قرار می گیرند که لیست آنها در جدول ۴ ارائه شده است.

در جدول ۵ نتایج حاصل از بررسی هر یک از بیمه نامه ها ارائه شده است. همانطور که مشاهده می شود، از مجموع ۱۱،۲۹۳ بیمه نامهٔ گندم آبی که منجر به دریافت خسارت شده، تعداد ۱۷۰ مورد به عنوان ناهنجاری تشخیص داده شده است. در بررسی صورت گرفته مشخص گردید از این تعداد ناهنجاری تعداد ۴۸ مورد ادعاهای خسارت نرمال بوده اند که به عنوان غیرنرمال تشخیص داده شده اند. همچنین از مجموع ۴،۷۲۷ بیمه نامهٔ گندم دیم که منجر به دریافت خسارت شده، تعداد ۹۷ مورد به عنوان ناهنجاری تشخیص داده شده است که در بررسی صورت گرفته مشخص گردید از این تعداد ناهنجاری تعداد ۳۱ مورد ادعاهای خسارت نرمال بوده اند که به عنوان غیرنرمال تشخیص داده است.

همان طور که مشاهده می شود، فراوانی ناهنجاری ها در بیمه نامه گندم آبی و دیم متفاوت از همدیگر هستند. این تفاوت ناشی از نوع کشت و تفاوت در خسارت های وارده می باشد. برای مثال، برای کشت دیم عامل خشکسالی از مهمترین عوامل دریافت خسارت است ولی در کشت آبی، طوفان و تگرگ مهمترین عامل دریافت خسارت می باشد.

مدل تشخیص ادعاهای مشکوک خسارت در بیمه کشاورزی

جدول ۴: دسته بندی ناهنجاری های تشخیص دادهشده

توضيح	شرح ناهنجاری	عنوان دسته– بندی	
بدین معنی است که مستندات لازم که می بایست طبق روشهای اجرایی در سامانه بارگذاری شود، موجود نمی باشد و یا برخی از آنها بارگذاری نشده است.	عدم وجود مستندات كافى	D١	
مستندات بارگذاری شده در سامانه طبق دستورالعمل مربوطه گویای بروز نوع خسارت ثبت شده نمیباشد. بهعنوان مثال، سرعت در خسارت طوفان ۶۰ کیلومتر بر ساعت ذکر شده، ولی در مدارک هواشناسی ۲۰ کیلومتر بر ساعت میباشد.	مستندات گویای وقوع خسارت اعلامی نمیباشد	DA	
در برخی از مستندات عامل خسارت در فرم کارشناسی خسارت خشکسالی عنوان گردیده، ولی عکس خسارت گویای خسارت سیل میباشد.	عدم مطابقت مستندات با واقعیت	D۳	
طبق دستورالعمل اجرایی، مهلت زمان اعلام خسارت تا زمان واریز غرامت به مدت یک ماه میباشد. خارج از آن مغایر با دستورالعمل میباشد.	عدم رعایت بازهٔ زمانی خسارت	T١	
طبق دستورالعملهای اجرایی صندوق بیمه، در خسارت زراعت میبایست یک هفته پس از بروز خسارت بازدید انجام شود؛ تا قبل از حذف آثار خسارت نوع و میزان آن بهصورت دقیق بررسی شود.	عدم مطابقت تاریخ وقوع خسارت با زمان اعلام خسارت	ΤΥ	

جدول ۵: نتایج بررسی موارد ناهنجار توسط کارشناسان

تعداد شخیص میزان دقت اشتباه	تعداد	داد آن	نوع ناهنجاری و تعداد آن			تعداد موارد	تحداد کا		
	تشخیص اشتباه	Т	T١	D۴	D۷	D١	تعداد کل ناهنجاری نمونهها شناسایی شده		نوع بيمهنامه
+/٧٢	۴۸	18	17	٨	١.	78	۱۷۰	11,798	گندم آبی
·/8A	٣١	۵	7.7	۴	٣	78	97	۶.۷۲۷	گندم دیم

جمع بندي و پیشنهادها

با توجه به هدف پژوهش که استفاده از تکنیکهای یادگیری ماشین بدون نظارت برای تشخیص ادعاهای دریافت خسارت غیرواقعی بود؛ نتایج بهدستآمده حاکی از وجود ۵ دسته رفتار غیرنرمال در پرداخت خسارت می باشد. بنابراین، با اتکا به این نتایج می توان پاسخ سؤالات پژوهش را این گونه داد.

در پاسخ به سؤال اول که در فرایند پرداخت خسارت بیمهٔ محصول گندم (دیم یا آبی) چه میزان ادعاهای مشکوک وجود دارد؟ می توان گفت که حدود ۱/۵ درصد از مجموع داده ها را موارد مشکوک یا غیرنرمال یا به عبارت دیگر ادعاهای خسارت غیرواقعی تشکیل می دهند. موارد مشکوک یافت شده برای محصول گندم آبی ۱۷۰ مورد و برای گندم دیم ۹۷ مورد بود. این موارد می تواند ناشی از رفتارهای نادرست از طرف ارزیاب، نمایندهٔ بیمه گر یا از طرف بیمه گذار باشد. روش های کلاهبرداری که در نتیجهٔ بررسی موارد غیرنرمال توسط کارشناسان به دست آمد را می توان به صورت زیر در Δ نوع دسته بندی کرد:

- ۱- عدم وجود مستندات کافی مبنی بر وقوع خسارت؛
- ۲- مستندات گویای وقوع خسارت اعلامی نمی باشد؛
 - ۲- عدم مطابقت مستندات با واقعیت؛
 - ۴- عدم رعایت بازهٔ زمانی خسارت؛
- ۵- عدم مطابقت تاریخ وقوع خسارت با زمان اعلام خسارت.
 در پاسخ به سؤال دوم که چگونه می توان از تکنیک های یادگیری ماشین برای تشخیص ادعاهای مشکوک خسارت در بیمهٔ

گندم استفاده کرد؟ می توان این گونه پاسخ داد که با استفاده از الگوریتم های یادگیری ماشین بدون نظارت که بهصورت ترکیبی مورد استفاده قرار گرفتند، مدل ساختهشده قادر به تشخیص ۷۲ درصد موارد مشکوک بیمه نامه های گندم آبی و ۶۸ درصد موارد مشكوك بيمهنامههاي گندم ديم مي باشد. البته ذكر اين نكته حائز اهمیت است که وقتی داده های مورد مطالعه دارای برچسب نیستند، ساخت مدل و ارزیابی دقت آن با چالش جدی مواجه است، لذا برای رفع این مسئله از کارشناسان و خبرگان بهره گرفته می شود. در این تحقیق نیز با توجه به اینکه داده ها دارای برچسب نبودند، ارزیابی نتایج با همکاری کارشناسان حوزهٔ بازرسی صندوق بیمهٔ کشاورزی، نتایج به صورت دقیق مورد بررسی قرار گرفتند. با توجه به حساسیت الگوریتم های یادگیری ماشین به تنظیمات ابَرپارامترها، استفاده از تخمین گرهای مختلف با تنظیمات متفاوت ابرپارامترها و ترکیب نتایج آنها مدل های باثبات تری را ارائه می دهند. در ترکیب نتایج از روشهای مختلفی از قبیل رأی اکثریت، آدابوست، بسته بندی می توان استفاده کرد. همچنین کمک گرفتن از کارشناسان خبرهٔ آن حوزه نیز در مواردی که داده ها برچسب ندارند، می تواند تأثیر بسزایی در ارزیابی نتایج به همراه داشته باشد.

پیشنهادهای زیر براساس تحقیق حاضر می تواند در بهبود روند تشخیص ادعاهای مشکوک خسارت مؤثر باشد:

۱- با وجود محدودیتهای ذکرشده، رویکرد بدون نظارت ارائهشده در این تحقیق می تواند با سامانه های موجود صندوق بیمهٔ کشاورزی ادغام شود و برای شناسایی ادعاهای مشکوک به صورت

غیربرخط مورد استفاده قرار گیرد.

۲- پیشنهاد می شود بهمنظور بهبود نتایج تجزیهوتحلیل، از دانشمندان داده برای انجام آماده سازی و پیش پردازش دقیق تر داده ها بهره گرفته شود.

۳- با ایجاد داده های برچسب دار برای تعدادی از داده ها در کنار انبوهی از داده های بدون برچسب، از روش های یادگیری ماشین نیمهنظارت شده بهره برداری شود، چراکه در بهبود نتیجه تأثیر مثبتی خواهد گذاشت.

۴-از آنجا که درصد زیادی از موارد غیرنرمال را دستهٔ اول، یعنی عدم ارائة مستندات كافي تشكيل مي دهد؛ لذا اين موضوع مي تواند ناشي از ارائة بیمه نامه های صوری و دریافت خسارت بدون ارائهٔ مستندات و با تبانی بیمه گذار، ارزیاب و نمایندهٔ بیمه گر صورت گرفته باشد. لذا ضروری است اصلالت زمین های مزروعی که بیمه می شوند توسط کارشناسان صندوق حین صدور بیمه نامه مورد تأیید قرار بگیرند.

۵- با مشخصشدن حدود اربعهٔ زمین های زراعی، مسئله تكرارىبودن داده ها مرتفع مى گردد؛ لذا پیشنهاد مى گردد داده هاى مربوط به حدود اربعهٔ زمین ها نیز در اختیار محققین قرار گیرد تا تجزیهوتحلیل دقیق تری روی داده ها صورت پذیرد.

انجام تحقیق حاضر با محدودیت هایی روبهرو بود. اول اینکه داده های موقعیت مکانی در دسترس نبود و درنتیجه زمین های زراعی بیمه شده که دارای مشخصات یکسانی بوده ولی در موقعیت های جغرافیایی متفاوتی بودند، به عنوان داده های تکراری مطرح شدند و از آنجا که داده های تکراری در آموزش مدل هیچ تأثیری ندارند، از مجموعهداده حذف شدند. همچنین عدم شناخت کافی صندوق بیمهٔ کشاورزی از میزان دقیق موارد کلاهبرداری (ادعاهای ساختگی یا سایر فرایندهای پرداخت) موجب شد تا میزان ناهنجاری های به دست آمده متفاوت از مقدار واقعی آن باشد؛ لـذا برای رسـیدن بـه بالاترین میـزان دقت تشخيص موارد غيرنرمال تحقيقات آينده، بايستي با لحاظنمودن ساير اطلاعات از قبيل تعداد دفعات دريافت خسارت توسط بیمه گذار، تضمین اصالت و مختصات جغرافیایی زمین های زراعے، و سایر ویژگی های کلیدی انجام شود.

این تحقیق با حمایت مالی صندوق بیمهٔ کشاورزی ایران انجام گرفته و بدین وسیله بابت این حمایت ها و همکاری های انجام شده در ارائهٔ داده ها و ارزیابی نتایج توسط کارشناسان حوزهٔ بازرسی، تقدیر و تشکر می گردد.

يعقوب احمدلو: جمع أورى مطالعات مرتبط و تدوين مدل، عليرضا

یورابراهیمی: کنترل چهارچوب تدوین و استانداردهای پژوهشی، جعفر

تنها: ارزیابی مدل ها و نتیجه گیری، یعقوب احمدلو: مروری بر ادبیات

پژوهش، علی رجب زاده قطری: روش پژوهش و متدولوژی.

نویسندگان اعلام می دارند که در مورد انتشار این مقاله تضاد منافع وجود ندارد. علاوه بر این، موضوعات اخلاقی شامل سرقت ادبی، رضایت آگاهانه، سوءرفتار، جعل دادهها، انتشار و ارسال مجدد و مکرر توسط نویسندگان رعایت شده است.

دسترسی آزاد

كپى رايت نويسنده (ها) ©2023: اين مقاله تحت مجوز بين المللي Creative Commons Attribution 4.0 اجازه استفاده، اشتراک گذاری، اقتباس، توزیع و تکثیر را در هر رسانه یا قالبی مشروط به درج نحوه دقیق دسترسی به مجوز CC منوط به ذکر تغییرات احتمالی بر روی مقاله میباشد. لذا به استناد مجوز مذکور، درج هرگونه تغییرات در تصاویر، منابع و ارجاعات یا سایر مطالب از اشخاص ثالث در این مقاله باید در این مجوز گنجانده شود، مگر اینکه در راستای اعتبار مقاله به اشکال دیگری مشخص شده باشد. در صورت عدم درج مطالب مذکور و یا استفاده فراتر از مجوز فوق، نویسنده ملزم به دریافت مجوز حق نسخهبرداری از شخص ثالث مي باشد.

به منظور مشاهده مجوز بین المللی Creative Commons Attribution 4.0 به آدرس زیر مراجعه گردد:

//https://creativecommons.org/licenses/by/4.0

Aggarwal, C.C., (2013). Outlier ensembles: Position paper. ACM SIGKDD explorations newsletter., 14(2): 49-58 (10 Pages).

Aggarwal, C.C.; Sahte, S., (2017). Outlier ensembles: An introduction. Springer.

The World Bank (2022). Agriculture & rural development.

Barbado, A.; Corcho, Ó.; Benjamins, R., (2022). Rule extraction in unsupervised anomaly detection for model explainability: Application to OneClass SVM. Expert Syst. Appl., 189(1): 1-20 (20 Pages).

Bauder, R.; Da Rosa, R.; Khoshgoftaar, T., (2018). Identifying medicare provider fraud with unsupervised machine learning. In 2018 IEEE international conference on information reuse and integration (IRI)., 285-292 (8 Pages).

Bose, I.; Mahapatra, R.K., (2001). Business data mining —A machine learning perspective. Inf. Manage., 39(3): 211-225

(15 Pages).

Bouazza, I.; Ameur, E.B.; Ameur, F., (2019). Datamining for fraud detecting, state of the art. Adv. Intell. Syst. Sustainable Dev., 205-219 (15 Pages).

Brownlee, J., (2020). Data preparation for machine learning. Chandola, V.; Banerjee, A.; Kumar, V., (2009). Anomaly detection: A survey. ACM Comput. Surv., 41(3): 1-58 (58 Pages).

Clayton, C., (2022). FBI touts work on crop insurance fraud case involving kentucky tobacco farmers. Insur. Agents.

Cole, S.A.; Xiong, W., (2017). Agricultural insurance and economic development. Annu. Rev. Econ., 9(1): 235-262 (28 Pages).

Bertoni, D., (2006). Crop insurance more needs to be done to reduce program's vulnerability to fraud, waste, and abuse. U.S. Gov. Account. Office., 1-18 (18 Pages).

Das, S.; Wong, W.K.; Dietterich, T.; Fern, A.; Emmott, A., (2016).

- Incorporating expert feedback into active anomaly discovery. In 2016 IEEE 16th international conference on data mining (ICDM)., 853-858 **(6 Pages).**
- Ertekin, S.; Huang, J.; Bottou, L.; Giles, L., (2007). Learning on the border: Active learning in imbalanced data classification. In Proceedings of the 16th ACM conference on conference on information and knowledge management., 127-136 (10 Pages).
- Gill, K.M.; Woolley, A.; Gill, M., (2005). Insurance fraud: The business as a victim?. Crime., 73-82 (10 Pages).
- Gill, W., (2009). Fighting fraud with advanced analytics. Can. Underwriter. Bus. Inf. Group., 76(9): 28-32 (5 Pages).
- Goodarzi, A.; Janatbabaei, S., (2017). Evaluation of Three Data Mining Algorithms (Decision Tree, Naive Bayes, Logistic Regression) in Auto Insurance Fraud Detection. Insur. Res., 1(2): 61-80 **(19 Pages).** [In Persian]
- Gomes, C.; Jin, Z.; Yang, H., (2021). Insurance fraud detection with unsupervised deep learning. J. Risk. Insur., 88(3): 591-624 (34 Pages).
- Han, J.; Kamber, M.; Pei, J., (2011). Data mining: Concepts and techniques. Morgan Kaufmann publishers Inc., 1-740 (740 Pages).
- Hassan, A.K.I.; Abraham, A., (2016). Modeling insurance fraud detection using ensemble combining classification. Int. J. Comput. Inf. Syst. Indust. Manage. App., 8(1): 257-265 (9 Pages).
- Hosseini, A.; Rezaei, A., (2019). Fraud detection and management strategies in the insurance organizations using data mining techniques. Social. Secur. Res. Inst., 14(4): 111-136 (26 Pages). [In Persian]
- Kim, D.; Lee, S.; Lee, J., (2020). An ensemble-based approach to anomaly detection in marine engine sensor streams for efficient condition monitoring and analysis. Sensors., 20(24): 1-16 (16 Pages).
- Kirlidog, M.; Asuk, C., (2012). A fraud detection approach with data mining in health insurance. Procedia. Social. Behav. Sci., 62(1): 989-994 (6 Pages).
- Li, J.; Huang, K.Y.; Jin, J.; Shi, J., (2008). A survey on statistical methods for health care fraud detection. Health care. Manage. Sci., 11(1): 275-287 (13 Pages).
- Liu, F.T.; Ting, K.M.; Zhou, Z.H., (2008). Isolation forest. In 2008 8th IEEE international conference on data mining., 413-422 (10 Pages).
- Marzen, C.G., (2013). Crop insurance fraud and misrepresentations: Contemporary issues and potential remedies. SSRN. Electron. J., 675-707 (33 Pages).
- Mouret, F.; Albughdadi, M.; Duthoit, S.; Kouamé, D.; Rieu, G.; Tourneret, J.Y., (2021). Outlier detection at the parcel-level in wheat and rapeseed crops using multispectral and sar time series. J. Remote Sens., 13(5): 1-25 (25 Pages).
- Müller, K.R.; Mika, S.; Tsuda, K.; Schölkopf, K., (2018). An introduction to kernel-based learning algorithms. In handbook of neural network signal processing., 1-4 (4 Pages).
- Nassif, A.B.; Talib, M.A.; Nasir, Q.; Dakalbab, F.M., (2021). Machine learning for anomaly detection: A systematic review.

- IEEE Access., 9(1): 78658-78700 (43 Pages).
- Ngai, E.W.T.; Hu, Y.; Wong, Y.H.; Chen, Y.; Sun, X., (2011). The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature. Decis. Support Syst., 50(3): 559-569 (11 Pages).
- Randhawa, K.; Loo, C.K.; Seera, M.; Lim, C.P.; Nandi, A.K., (2018). Credit card fraud detection using adaboost and majority voting. IEEE Access., 6(1): 14277-14284 (8 Pages).
- Rejesus, R.M.; Little, B.B.; Lovell, A.C., (2004). Using data mining to detect crop insurance fraud: Is there a role for social scientists?. J. Financ. Crime., 12(1): 24-32 (9 Pages).
- Roholamin, M.; Paygozar, H.; Khalili Dermani, M.K., (2019). An overview of fraud detection methods in the insurance industry. Paper presented at the 3rd national conference on electrical and computer engineering., 1-10 (10 Pages). [In Persian]
- Rostami, H.; MonazamiTabar, S., (2021). Insurance fraud in the compulsory insurance law (2016) (by looking at the american legal system). Iran. J. Insur. Res., 10(3): 155-186 (32 Pages). [In Persian]
- Ruff, L.; Kauffmann, J.R.; Vandermeulen, R.A.; Montavon, G.; Samek, W.; Kloft, M.; Dietterich, D.G.; Müller, K.R., (2021). A unifying review of deep and shallow anomaly detection. Proc. IEEE., 109(5): 756-795 (40 Pages).
- Sahni, S.; Mittal, A.; Kidwai, F.; Tiwari, A.; Khandelwal, K., (2020). Insurance fraud identification using computer vision and IOT: A study of field fires. Procedia. Comput. Sci., 173(1): 56-63 (8 Pages).
- Schölkopf, B.; Platt, J.C.; Shawe-Taylor, J.; Smola, A.J.; Williamson, R.C., (2001). Estimating the support of a high-dimensional distribution. Neural Comput., 13(7): 1443-1471 (29 Pages).
- Schölkopf, B.; Williamson, R.C.; Smola, A.; Shawe-Taylor, J.; Platt, J., (1999). Support vector method for novelty detection. Adv. Neural. Inf. Process. Syst., 582-588 (7 Pages).
- Soltani Halvaiee, N.; Akbari, M.K., (2014). A novel model for credit card fraud detection using artificial immune systems. Appl. Soft Comput., 24(1): 40-49 (10 Pages).
- Verma, A.; Taneja, A.; Arora, A., (2017). Fraud detection and frequent pattern matching in insurance claims using data mining techniques. Paper presented at the 2017 10th international conference on contemporary computing (IC3)., 1-7 (7 Pages).
- Zhao, Y.; Hu, X.; Cheng, C.; Wang, C.; Wan, C.; Wang, W.; Yang, J.; Bai, H.; Li, Z.; Liao, C.; Wang, Y.; Qiao, Z.; Sun, J.; Akoglu, L., (2021). Suod: accelerating large-scale unsupervised heterogeneous outlier detection. Proc. Mach. Learn. Syst., 463-478 (16 Pages).
- Zhao, Y.; Nasrullah, Z.; Hryniewicki, M.K.; Li, Z., (2019). LSCP: Locally selective combination in parallel outlier ensembles. Proceedings of the 2019 SIAM international conference on data mining (SDM)., 585-593 (9 Pages).
- Zhao, Y.; Nasrullah, Z.; Li, Z., (2019). Pyod: A Python toolbox for scalable outlier detection. J. Mach. Learn. Res., 1-7 (7 Pages).

معرفي نويسندگان AUTHOR(S) BIOSKETCHES

یعقوب احمدلو، دانشجوی دکتری مدیریت فناوری اطلاعات، گروه مدیریت فناوری اطلاعات، دانشکدهٔ مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران ایران

■ Email: Y.ahmadlou@srbiau.ac.ir

• ORCID: 0000-0002-3778-094X

■ Homepage: https://srb.iau.ir/management/fa

علیرضا پورابراهیمی، استادیار گروه مدیریت صنعتی، دانشکدهٔ مدیریت و حسابداری، واحد کرج، دانشگاه آزاد اسلامی، کرج، ایران

■ Email: A.pourebrahimi@kiau.ac.ir

• ORCID: 0000-0001-5741-0260

• Homepage: http://www.alirezapourebrahimi.ir

جعفر تنها، دانشیار گروه مهندسی فناوری اطلاعات، دانشکدهٔ مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

■ Email: *Tanha@tabrizu.ac.ir*

• ORCID: 0000-0002-0779-6027

• Homepage: https://asatid.tabrizu.ac.ir/fa/pages/default.aspx?tanha

على رجبزاده، استاد گروه مديريت صنعتى، دانشكدهٔ مديريت و اقتصاد، دانشگاه تربيت مدرس، تهران، ايران

■ Email: Alirajabzadeh@modares.ac.ir

ORCID: 0000-0002-8470-3568

Homepage: https://www.modares.ac.ir/pro/academic_staff/alirajabzadeh

HOW TO CITE THIS ARTICLE

Ahmadlou, Y.; Pourebrahimi, A.; Tanha, J; Rajabzadeh, A., (2023). An ensemble based model for detecting suspicious claims in crop insuranc. Iran. J. Insur. Res., 12(1): 63-78.

DOI: 10.22056/ijir.2023.01.06

URL: https://ijir.irc.ac.ir/article_155353.html?lang=en

